

# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ  
ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ

FACULTY OF INFORMATION TECHNOLOGY  
DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

## ALGORITMICKÉ OBCHODOVÁNÍ NA BURZE

BAKALÁŘSKÁ PRÁCE  
BACHELOR'S THESIS

AUTOR PRÁCE  
AUTHOR

PETER ĎURIAČ

BRNO 2014



**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**  
BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA INFORMAČNÍCH TECHNOLOGIÍ**  
**ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ**

FACULTY OF INFORMATION TECHNOLOGY  
DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

# **ALGORITMICKÉ OBCHODOVÁNÍ NA BURZE**

ALGORITHMIC TRADING

## **BAKALÁŘSKÁ PRÁCE**

BACHELOR'S THESIS

## **AUTOR PRÁCE**

AUTHOR

**PETER ĎURIAČ**

## **VEDOUCÍ PRÁCE**

SUPERVISOR

**Ing. IGOR SZÖKE, Ph.D.**

BRNO 2014

## Abstrakt

Táto práca sa zaoberá využitím neurónových sietí, pri predpovedi vývoja ceny na burze a následným testovaním pomocou zvolenej platformy na reálnom demo účte. Je tu popísaná základná teória obchodovania na burze. Ďalej je v práci popísaná teória fungovania neurónových sietí. V praktickej časti je vytvorená neurónová sieť a k nej sú navrhnuté dva obchodné modely. Tieto modely sú simulované na zvolených dátach a výsledky sú porovnané s obchodným modelom človeka. Následne sú vytvorené obchodné systémy otestované v reálnom obchodovaní pomocou zvolenej obchodnej platformy. Výsledky simulácií sú porovnané s dosiahnutými reálnymi výsledkami. Nakoniec sú navrhnuté ďalšie smery vývoja systému.

## Abstract

The Bachelor thesis focuses on the utilization of neural networks in prediction of stock market price development and then testing by means of chosen platform on the real demo account. In this thesis is described the basic theory of stock market trading as well as theory of neural network functioning. The neural network is created and to this network are designed two trading models. These models are simulated on the chosen data and results are compared with trading model of a human. Consequently, created trading systems are tested in the real trading by means of chosen trading platform. Results of simulation are compared with reached real results. Another orientation of system development is designed.

## Klíčová slova

Predpoveď vývoja kurzu, umelá neurónová sieť, intradenné obchodovanie, obchodovanie na burze.

## Keywords

Market prediction, artificial neural network, intraday trading, stock trading.

## Citace

Peter Ďuriač: Algoritmické obchodování na burze, bakalářská práce, Brno, FIT VUT v Brně, 2014

# Algoritmické obchodování na burze

## Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracoval samostatně pod vedením Ing. Igor Szöke, Ph.D. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

.....

Peter Ďuriač  
19. května 2014

## Poděkování

Touto cestou by som sa chcel poďakovať môjmu vedúcemu Ing. Igor Szöke, Ph.D. za ochotu pri konzultáciach, poskytnuté rady a návrhy. A za všetok čas, ktorý mi venoval, keď to bolo potrebné.

© Peter Ďuriač, 2014.

*Tato práce vznikla jako školní dílo na Vysokém učení technickém v Brně, Fakultě informačních technologií. Práce je chráněna autorským zákonem a její užití bez udělení oprávnění autorem je nezákonné, s výjimkou zákonem definovaných případů.*

# Obsah

<b>1 Úvod</b>	<b>3</b>
<b>2 Burza a obchodovanie</b>	<b>5</b>
2.1 Základné pojmy . . . . .	5
2.2 Technická analýza . . . . .	7
2.2.1 grafy . . . . .	7
2.2.2 Indikátory a typy obchodov . . . . .	7
2.3 Použité indikátory . . . . .	8
2.3.1 Dvojité klzavé priemery - Systém 5&20 . . . . .	9
2.3.2 CCI - Commodity Channel Index . . . . .	9
2.3.3 Envelopes . . . . .	11
<b>3 Umelé neuronové siete</b>	<b>12</b>
3.1 Biologická neurónová bunka . . . . .	12
3.2 Umelá neurónová bunka . . . . .	13
3.3 Princíp práce umelej neurónovej siete . . . . .	14
3.4 Back-propagation . . . . .	14
3.5 Použitie Neurónových sietí na predikciu . . . . .	16
<b>4 Praktická časť</b>	<b>18</b>
4.1 Obchodná platforma . . . . .	18
4.2 Meta Trader a Neurónové siete . . . . .	19
4.3 Výber trhu a testovacie dáta . . . . .	20
4.4 Priebeh testovania . . . . .	21
4.5 Obchodný systém človeka . . . . .	22
4.6 Systém použitý v NN . . . . .	23
4.6.1 Koncepčia modelu . . . . .	24
4.6.2 Príprava dát . . . . .	24
4.6.3 Vstupné hodnoty NN . . . . .	25
4.6.4 Výstupné hodnoty NN . . . . .	25
4.6.5 Zostavenie NN . . . . .	25
4.6.6 Navrhnuté obchodné modely . . . . .	26
4.6.7 Výsledky simulácií . . . . .	27
4.6.8 Obchodovanie na demo účte . . . . .	28
4.6.9 Porovnanie výsledkov . . . . .	30
4.6.10 Návrh ďalšieho vývoja . . . . .	31
<b>5 Záver</b>	<b>33</b>



# Kapitola 1

## Úvod

Obchodná činnosť alebo obchodovanie je činnosť kúpy a predaja. Stretáva sa tu záujem predávajúceho a kupujúceho. Objekt záujmu sa nazýva tovar. Kupujúci chce tovar kúpiť, predávajúci má záujem tovar predať. Táto výmena je realizovaná platidlom, najčastejšie peniazmi, za dohodnutú cenu. Cena je suma, za ktorú je predávajúci ochotný svoj tovar predať a zároveň kupujúci je ochotný za tovar dať.

Obchodovanie tovarov je dnes bežné a môžeme sa s ním stretnúť takpovediac všade. Rozdiel je v tom, s čím a kde obchodujeme. Obchod môžeme uskutočniť ako koncoví užívateľ v predajniach s tovarmi každodennej potreby. Obchodovať môžeme aj u producentov tovarov a následne tovary ďalej šíriť. V neposlednom rade môžeme obchod uskutočňovať na burzách. Kde sa ako tovar označujú komodity, fondy, meny, akcie, akciové indexy a mnohé iné.

Obchodovanie nie je investovanie, aj keď sa oba pojmy často označujú rovnako. Hlavný rozdiel je časový horizont. Investovaním môžeme označiť dlhodobý nákup v časovom horizonte od niekoľko týždňov, či mesiacov, ale aj rokov. Naopak, za obchodovanie sa považuje držba tovaru niekoľko minút, hodín, či dní<sup>1</sup>.

Obchodovanie na burze nie je výdobytok dnešnej modernej doby. Prvá burza v Amsterdame bola otvorená už v roku 1611<sup>2</sup>. Výdobytky dnešnej doby iba ponúkajú väčšie možnosti a urýchľujú celý proces. Vďaka internetu, dnes už nie je potrebné fyzicky byť prítomný v budove burzy. Existuje mnoho brokerov, ktorí poskytujú svoje služby pomocou elektronických platforiem.

Zapojenie IT do obchodovania na burze, nám poskytuje možnosť využiť oblasť umelej inteligencie a vytvoriť umelú neurónovú sieť, za účelom maximalizovania obchodných ziskov. Toto zo sebou prináša aj riziká v podobe strát. Ako sa napríklad stalo spoločnosti Knight Capital Group, keď počas 45 minút prišla o 460 miliónov dolárov<sup>3</sup>. Preto je vždy potrebné postupovať s maximálnou opatrnosťou.

Táto práca nadväzuje na diplomovú prácu [4], ktorá pojednáva o predpovedi vývoja kurzu s použitím umelých neurónových sietí. Autor vo svojej práci porovnával svoje výsledky s náhodnými výsledkami a výsledkami ľudského obchodného prístupu na historických dátach. Došiel k záveru, že s pomocou neurónových sietí je možné, zo štatistického pohľadu predpovedať vývoj kurzu dostatočne uspokojivo. Autor poukazuje na mnohonásobne väčší potenciál trhov a vidí možnosť zlepšenia voľbou optimálnej kombinácie vstupných a výstupných dát.

Táto práca sa zaoberá hľadaním vhodnej kombinácie vstupných a výstupných dát v

---

<sup>1</sup><http://akademia.trimbroker.com/keyword/obchodovanie>

<sup>2</sup><https://www.nyx.com/en/who-we-are/history/amsterdam>

<sup>3</sup><http://www.root.cz/zpravicky/programatorska-chyba-zpusobila-ztratu-460-milionu-usd/>

predpovedi vývoja kurzu trhu. Práca je zameraná na intradenné obchodovanie prevažne s akciovými indexami. Ďalej v tejto práci bude tento systém otestovaný na demo účte, v ktorom sú podmienky rovnaké ako v reálnom obchodovaní, ale nehrozí riziko straty kapitálu.



## Kapitola 2

# Burza a obchodovanie

Pri pohybe a obchodovaní na burze obchodník prichádza do kontaktu s mnoho špecifickými výrazmi na každom kroku. Tieto pojmy sú používané komunitou obchodníkov a pre ostatných ľudí môžu mať nejasný význam. Aby nedochádzalo k nedorozumeniam je potrebné poznať ich presný význam.

### 2.1 Základné pojmy

Na začiatok je potrebné si ujasniť kde a ako sa dá obchodovať: <sup>1</sup>.

- **Burza** - Slovo burza má viacero rozličných významov, napríklad v biológii, kresťanstve. Nás bude zaujímať význam ekonomický. Je to miesto, na ktorom sa za striktného dohľadu kontrolných orgánov uskutočňujú jednotlivé obchody. V USA zabezpečuje kontrolu orgán CFTC (Commodity futures trading commission) <sup>2</sup>. Na burze sa obchoduje prostredníctvom sprostredkovateľa.
- **Broker/maklér** - je registrovaný sprostredkovateľ obchodných transakcií. Je to tá osoba/spoločnosť, vďaka ktorej môžeme vykonávať obchody na burze. Poskytuje nám finančné služby, za ktoré si účtuje partičné poplatky. Tieto poplatky je potrebné zaradiť do výslednej ceny obchodu. Rôzni poskytovatelia majú rôzne poplatky. Z dlhodobého hľadiska je dôležité vybrať si poskytovateľa s nízkymi poplatkami, ale aby to nebolo na úkor poskytovaných služieb.
- **Pozičné obchodovanie** - držanie otvorenej pozície po dobu dlhšiu ako jeden deň. <sup>3</sup>
- **Intradenné obchodovanie** - obchodovanie primárne počas dňa. Pozície sú otvorené niekoľko minút, maximálne pár hodín.

Základné vlastnosti finančných trhov: <sup>4</sup>.

- **Cena trhu** - cena je vždy udávaná v bodoch (ang. pips).
- **Tick** - minimálny pohyb trhu.
- **Lot** - minimálne obchodovateľné množstvo cenných papierov.

---

<sup>1</sup><http://www.financnik.cz/wiki/glosar>

<sup>2</sup><http://www.cftc.gov/About/MissionResponsibilities/index.htm>

<sup>3</sup><http://www.financnik.cz/komodity/manual/komodity-pozicni-vs-intradenni-obchodovani.html>

<sup>4</sup><http://www.financnik.cz/wiki/glosar>

- **Trend** -je smer, ktorým sa trh ubera. Určenie smeru trendu je individuálna záležitosť. Záleží na osobných preferenciách obchodníka aké indikátory použije a na akom časovom meradle pracuje. Potom rozlišujeme *Medvedí (bear) trh*, to je každý trh, ktorý klesá. Naopak, každý trh ktorý stúpa sa nazýva *Býčí (bull) trh*.
- **Margin** - vratná záloha umožňujúca ovládať komoditný kontrakt. Nie je to poplatok. Margin určuje burza alebo broker.
- **Spread** - rozdiel medzi nákupnou a predajnou cenou.
- **Stop-loss** - je dopredu definovaná krajná hranica, pri ktorej dobrovoľne inkasujeme malú stratu skôr, ako sa táto strata rozrastie do obrovských rozmerov. Ak by sme obchodovali bez stop-lossu, tak je naša strata potenciálne neobmedzená. Základný účel stop-lossu je ochrana nášho kapitálu.
- **Time frame** - je časové meradlo grafu. Pokiaľ intradenný obchodník využíva sviečkový graf a time-frame 1 minúta, tak to znamená, že každá zobrazená sviečka predstavuje zmenu ceny za jednu minútu

Indikátory a ďalšie vlastnosti, ktoré by mali byť brané v úvahu pri výbere konkrétneho trhu pre obchodovanie: <sup>5</sup>.

- **Volatilita** - kolísavosť časového radu. Udáva aký živý je trh.
- **Likvidita** - likvidný trh je taký, v ktorom sa živo obchoduje. Jeden konkrétny obchod nemá príliš vplyv na zmenu ceny. Dostatočne likvidný trh umožňuje obchodníkovi otvoriť alebo uzavrieť pozíciu v podstate v ľubovoľnej chvíli. Ak je trh málo likvidný, môže to zapríčiniť, že naša pozícia sa uzavrie v iný časový okamžik, keď aj cena bude iná, čo môže byť aj za výrazne horšiu cenu. Preto je potreba obchodovať iba na dostatočne likvidných trhoch.
- **Margin** - je určitá záloha, za ktorú nám broker umožní obchodovať daný instrument. Po dobu obchodu je táto záloha zablokovaná, po ukončení obchodu je okamžite uvoľnená. Jej funkcia je ako poistka pre brokera, aby vždy bolo z čoho pokryť prípadné straty
- **Rezistencia** - jedná sa o bod na grafe kde cena vzdorovala ďalšiemu rastu. Je to určitý strop, najvyššia cena, ktorú je väčšina obchodníkov ochotná za nákup daného tovaru zaplatiť.
- **Support** - je to opak rezistencie. Bod na grafe, kde cena vzdoruje proti ďalšiemu poklesu. Je to určitá podlaha. Pod touto cenou sa obchodníci zdráhajú predávať svoje tovary.
- **Volume** - objem obchodov zrealizovaných v rámci zvolenej time-frame.

Na burzách môžeme obchodovať s viacerými položkami: [2]

- **Akcie** - obchodovanie s cennými papiermi firiem. Výhodou akcií je, že existuje obrovské množstvo titulov, ktoré môžeme obchodovať. Nevýhodou je, že trhy s akciami sú ovplyvňované fundamentálnymi prvkami.

---

<sup>5</sup><http://www.financnik.cz/wiki/glosar>

- **Komodity** - obchodovanie so surovinami, ako je ropa, pšenica, zlato a iné.
- **ETFs** - skratka znamená Exchange Traded Funds, čo sa prekladá ako fondy obchodované na burzovom trhu. Sú to fondy zameriavajúce sa na určitú špecifickú časť trhu, ktorej vývoj potom veľmi tesne sledujú.
- **Indexy** - ceny indexov predstavujú váženú hodnotu určitého súboru akcií. Je to matematicky vypočítaná hodnota. Nemožno ich obchodovať priamo, ale pomocou odvodených finančných nástrojov, ako je napríklad akciový index.
- **Meny** - môžeme obchodovať cez centralizovaný trh v podobe *komoditných kontraktov na meny*, ale cez nentralizovaný *forexový trh*.
- a ďalšie...

## 2.2 Technická analýza

Rozlišujeme tri základné druhy analýz trhov. Psychologická analýza, fundamentálna analýza a technická analýza. Psychologická analýza skúma človeka. Aké faktory vedú investorov nakupovať alebo predávať. Snaží sa odpovedať na otázku, čo budú robiť ostatní. Fundamentálna analýza pracuje s fundamentálnymi dátami ako sú tržby, zisky, predpokladaný zisk ale napríklad aj počasie. Pri komoditnom predaji kukurice je počasie dôležitým faktorom ovplyvňujúcim cenu. Tieto spôsoby sú nevhodné pre automatický obchodný systém. Pre nás je výhodná technická analýza, ktorá vychádza zo štúdia grafov. Na grafoch môžeme vyhľadávať známe cenové vzory a vypočítať technické indikátory. Indikátory nám uľahčujú vyhľadávanie cenových vzorov.

### 2.2.1 grafy

Každý obchodník sa musí vedieť orientovať v grafoch. Z dôvodu väčšej výpovednej hodnoty veľa obchodníkov pri svojej analýze používa sviečkové grafy (ang. japanese candlestick) obr 2.1. Každá sviečka znázorňuje vývoj ceny počas daného časového obdobia obr 2.2. Minimum(low) a maximum(high), kam sa dostala cena vo zvolenom období nám zobrazuje čiara grafu tzv. knôť. Telo grafu sviečkových hodnôt zobrazuje rozdiel medzi otváracou a uzatváracou cenou za danú periodu. Ak je cena otvorenia(open) nižšia ako cena uzavretia(close) nazýva sa táto sviečka býčia a je zvyčajne modrej farby. Naopak ak je cena otvorenia vyššia ako cena uzavretia ide o medveďiu sviečku a jej farba býva červená<sup>6</sup>.


### 2.2.2 Indikátory a typy obchodov

Indikátory nám pomáhajú v rozhodovaní. Na ich základe sa rozhodujeme kedy a do akej pozície vstúpime. Do obchodu môžeme vstúpiť dvoma spôsobmi:


**Vstup na dlhú stranu(long)** - predpokladáme rast ceny trhu. Je to nákup jedného alebo viacerých kontraktov. Ak cena naozaj stúpane, obchod je ziskový. Ak cena klesá, zväčšuje sa aj strata.

**Vstup na krátku stranu(short)**- predpokladáme pokles ceny. Je to predaj kontraktu, pričom kontrakt nemusíme vlastniť, ale zaväzuje nás to k neskoršiemu nákupu. Ak cena naozaj poklesne, obchod je ziskový, naopak ak cena stúpane dostávame sa do straty.

<sup>6</sup><http://en.tradimo.com/learn/candlesticks/how-to-read-candlesticks>



Obrázek 2.1: V pravo medvedia sviečka a vľavo býčia sviečka



Obrázek 2.2: Jednodňový graf trhu S&P Zdroj [www.stockrageous.com](http://www.stockrageous.com)

Technických indikátorov existuje obrovské množstvo. Obchodník má možnosť používať jeden, alebo aj kombináciu viacerých. Podľa Alexandra Eldera, celosvetovo uznávaného obchodníka zameriavajúceho sa na technickú analýzu, je 4-6 indikátor ten ideálny počet<sup>7</sup>.

## 2.3 Použité indikátory

Pri výbere indikátor v tejto práci sme sa inšpirovali výsledkami diplomovej práce, na ktorú táto práca nadväzuje.<sup>[4]</sup> A tiež sme sa inšpirovali aj indikátormi ktoré, používajú svetoznámi, úspešní obchodníci. Všetky indikátory sme otestovali najprv na historický graf na papiery a neskôr vybrané indikátory sme testovali pomocou aplikácie forex tester, ktorá vo svojej voľne šíriteľnej verzii ponúka testovania na 3 menových pároch v období jeden mesiac. Táto práca sa nebude zameriavať na obchodovanie s forexom, ale z pohľadu technickej analýzy a testovania indikátorov nieje dôležité na akom grafe sa testuje.

<sup>7</sup><http://www.youtube.com/watch?v=yCbAteEgqBQ&list=PL82BB802A376B592F&index=57>

### 2.3.1 Dvojité klzavé priemery - Systém 5&20

Dvojité klzavé priemery využívajú dva rozdielne jednoduché klzavé priemery, nazývané tiež MA (moving averages), v tandeme. Prvý z týchto dvoch priemerov slúži ako rýchlejší, využíva kratšie časové obdobie. Druhý slúži ako pomalší a jeho časové obdobie je teda dlhšie. Signálom na vstup do pozície je situácia, keď rýchlejší klzavý priemer prekríži pomalší klzavý priemer. Keď rýchlejší klzavý priemer pretne pomalší klzavý priemer smerom nahor je to signál k nákupu. V opačnom prípade keď rýchlejší pretne pomalší smerom nadol je to signál k predaju<sup>8</sup>. Systém je jednoduchý, otázkou ostáva, ako si zvoliť správne časové obdobia? V tomto nám pomôže obchodník Richard Donchian, ktorý je považovaný za otca trendového obchodovania. Pán Donchian dlhoročným študovaním a testovaním prišiel k záveru, že najlepšie úspechy dosiahol s nastavením 5 a 20. Systém generuje veľa signálov z ktorých väčšina je stratových, ale na druhú stranu systém dokáže zachytiť počiatky dlhodobých trendov, ktoré generujú nemalý zisk a bohaté kompenzujú predošlé straty<sup>9</sup>. Príklad je ilustrovaný na obrázku 2.3.



Obrázok 2.3: Systém 5&20 vždy keď rýchlejší klzavý priemer (červená čiara), prekríži pomalší klzavý priemer (fialová čiara) je to považované za signál k vstupu do pozície, prípadne výstupu z pozície. Zdroj: [www.finančník.cz](http://www.finančník.cz)

### 2.3.2 CCI - Commodity Channel Index

Tento indikátor meria vzťah ceny podkladového aktíva, jeho klzavého priemeru a štandardnej odchýlky. Slúži na vyjadrenie toho kedy je aktívum prekúpené resr. prepredané. CCI nemá stanovené hranice, čím sa výrazne líši od podobných indikátorov. Do praxe ho zaviedol Donald Lambert<sup>10</sup>. Samotný výpočet sa skladá z viacerých častí. Najprv je potreba

<sup>8</sup><http://www.finančník.cz/komodity/manual/komodity-klouzave-prumery.html>

<sup>9</sup>[www.finančník.cz/komodity/strategie/komodity-obchodni-system-donchian.html](http://www.finančník.cz/komodity/strategie/komodity-obchodni-system-donchian.html)

<sup>10</sup><http://www.patria.cz/zpravodajstvi/1894121/ocilator-cci—popularni-pomocnik-pri-forexovem-obchodovani.html>

vypočítať tzv. typickú cenu(TC):

$$TC = \frac{(High + Low + Close)}{3} \quad (2.1)$$

Ďalší krok je výpočet priemernej absolútnej odchýlky(PAO) ako typická cena v čase  $i$  a jednoduchý kľzavý priemer za posledných  $n$  period z typickej ceny:

$$PAO = \frac{\sum_{i=1}^n (TP_i - SMA(n, TP))}{n} \quad (2.2)$$

Typická cena a priemerná absolútna odchýlka následne vstúpia do výsledného vzorca CCI. Vo vzorci sa vyskytuje konštanta, ktorú nastavil Donald Lambert, aby väčšina hodnôt spadla do intervalu -100 až 100:

$$CCI = \frac{TP - SMA(n, TP)}{0,015 * PAO} \quad (2.3)$$

Existuje mnoho variáci CCI. Čím nižšie je nastavenie CCI, tým volatilnejším sa indikátor stáva a produkuje viac signálov. V praxi často obchodníci používajú nastavenie 14, pričom keď hodnota indexu presiahne 100 bodov považuje sa aktívum za prekúpené. Naopak ak presiahne -100 bodov považuje sa za prepredané.



Obrázek 2.4: Indikátor CCI Zdroj: [www.dailyfx.com](http://www.dailyfx.com)

### 2.3.3 Envelopes

Tento indikátor je veľmi jednoduchý. Pozostáva z dvoch exponenciálnych kĺzavých priemerov(EMA), resp. z dvoch variácií jedného priemeru<sup>11</sup>. Výpočet:

$$Hornoblka = EMAX + y\% \quad (2.4)$$

$$Dolnoblka = EMAX - y\% \quad (2.5)$$

Základný predpoklad využitia indikátora predpokladá, že cena sa zvykne pohybovať okolo svojho kĺzavého priemeru a v blízkych hraniciach. Pri prekročení sa vracia späť do normálu. Tento indikátor pri svojich obchodoch využíva už aj spomenutý Alexander Elder, ktorý používa EMA(21).



Obrázek 2.5: modrá čiara - horná obálka, červená čiara - dolná obálka

<sup>11</sup><http://www.etrading.sk/technicka-analyza/44-indikatory-technickej-analyzy/95-envelopes-obalky>


## Kapitola 3

# Umelé neuronové siete

Technický pojem umelé neuronové siete(ďalej NN) úzko súvisí s ich ekvivalentom biologické neurové siete. Súvislosť je v ich štruktúre a spôsobe medzineurónovej komunikácie. Využitie NN sa uplatňuje na miestach kde matematický problém môžeme len veľmi obtiažne popísať, alebo je matematické riešenie priveľmi náročné. NN tak ako aj biologické neuronové siete majú schopnosť učiť sa. To znamená, že môžeme využiť získané znalosti na riešenie podobných problémov aj bez znalosti algoritmickeho riešenia úlohy. V praxi sa udomácnilo použitie v *predpovediach*, kde sa predpovedá výstupná hodnota na základe priebehu veličín v minulosti. NN pracuje v dvoch základných fázach. Vo *filtrácii* vyhladzuje priebeh vstupného signálu. V *rozpoznávaní (klasifikácia)* na základe vstupného vektoru rozhoduje o tom, do ktorej kategórie daný predmet zaradiť.

### 3.1 Biologická neurónová bunka

Nervová bunka má "telo"(s jadrom) a dva druhy prenosových vlákien, obrázok 3.1. Aktívne vlákno, axón, sa na svojom vzdialenejšom konci vetví a napojuje sa prísavnými telieskami(synaptickými telieskami) na pasívne vlákna,dendridy, iných neurónov. Dendridy pôsobia ako vstupné kanály neurónu, axón ako výstupný. Doposiaľ jediné uspokojujúce vysvetlenie mechanizmu prenosu správ poskytli zákony elektromagnetických procesov. Počet neuronových buniek v ľudskom mozgu sa stále iba odhaduje[3].



Obrázek 3.1: Nervová bunka




## 3.2 Umelá neurónová bunka

Tak ako aj v biologickom svete, aj vo svete umelej inteligencie je základná stavebná jednotka neurón. Skladá sa z troch čiastkových funkcií. A to zo *vstupnej funkcie*  $F_t$ , nazývanej tiež agregáčnā. Umelý neuron je vybavený konečným počtom vstupov  $X_i$  a ich váhami  $W_i$ . Táto funkcia sa starā o prevedenie vstupných veličín, na veličinu ktorā spracováva *aktivačná funkcia*  $F_a$ . Matematicky sa dá vyjadriť nasledovne:

$$F_t(k) = \sum_{i=1}^n x_i(k) * w_i(k) \quad (3.1)$$

Výstup z aktivačnej funkcie sa poskytne *výstupnej funkcií*  $F_o$ . Tá vstup prevedie na veličinu, ktorā sa bude ďalej šíriť.



Obrázek 3.2: Umelā neurónová bunka

Neurónové siete sú schopné rozpoznávať zložité štrukturálne obrazce. Vstupy neurónov sú v podstate číselné. Stretávame sa s tromi druhmi vstupov:

- **Kvalitatívne vstupy** - nabývajú hodnoty z číselnej množiny  $\{-1, +1\}$ . Každý vstup sa viaže k určitej manifestácii niektorej vlastnosti. Hodnoty vyjadrujú existenčný stav tejto manifestácie. -1 znamená že objekt danú manifestáciu nemá, naopak +1 znamená, že ju má.
- **Fuzzy kvalitatívne vstupy** - fuzzy hodnoty jazykových premenných zavedených na univerzách systémových premenných.
- **Kvantitatívne vstupy** každý vstup môže byť modifikovaný váhou  $W_{i,j}$ , ktorá reprezentuje citlivosť, s akou môže pôsobiť na výstup neurónu.

Pomocou umelých neurónov, vytvárame neurónové siete. V sieti na neuróny delia na *vstupné*, *skryté* a *výstupné*. Návrh topológie siete sa vo všeobecnosti rozlišuje do dvoch základných skupín:

- **Dopredné NN** - anglicky nazývané feed-forward. Signál sa šíri po prepojeniach iba jedným smerom a to dopredu.
- **Rekurentné NN** - rozdelenie vrstiev je obtiažne, lebo neuróny niekedy môžu byť vstupného, a v inom prípade výstupného typu súčasne. Pripúšťajú šírenie signálu oboma smermi.

Šírenie signálu môže byť rozmanité. Najčastejšie spôsoby šírenia sú:

- **Synchrónne** - všetky neuróny menia svoj stav do taktu, pomocou synchronizačných hodín.
- **Sekvenšné** - neuróny menia svoj stav postupne pri šírení signálu.
- **Blok-sekvenšné** - aktivujú sa iba skupiny neurónov, podľa dopredu zvolenej stratégie.
- **Asynchrónne** - neuróny menia svoje stavy nesynchronizovane, úplne nezávisle jeden od druhého.

### 3.3 Princíp práce umelej neurónovej siete

Umelá neurónová sieť pracuje v dvoch fázach. Prvá fáza je *adaptívna*, kde sa sieť učí. Do pamäte si ukladá rôzne vzory. Druhá fáza je *aktívna*, kde sieť vykonáva naučenú činnosť. Vybavuje ten najpodobnejší vzor. To znamená, že umelá neurónová sieť si vie poradiť aj s neexistujúcim vzorom. Ako pamäť sú najčastejšie uvažované váhové hodnoty koeficientov jednotlivých vstupov neurónu. [1]

**Učenie** - v NN sa realizuje nastavovaním váh medzi uzlami. Na začiatku sa váham priradia počiatočné hodnoty, často náhodne zvolené. Potom sa do NN privedie tréningový vstup. Sieť poskytne výstup. Existujú dva typy učenia, učenie s učiteľom a bez učiteľa.

*Učenie s učiteľom* - existuje vnútorné kritérium, ktoré určuje správnosť výstupu. Váhy sa nastavujú pomocou spätnej väzby, podľa toho, ako blízko je výstup k danému kritériu. Vypočíta sa rozdiel vo výstupe, ktorý poskytla sieť a skutočným výstupom. Pomocou algoritmu sa upraví hodnota váh. Používané algoritmy sú napríklad: učenie s korekciou chyby, stochastické učenie alebo Back-propagation. Ďalej sa do siete predloží nový výstup a celý proces sa opakuje. Po uskutočnení veľkého počtu pokusov sa sieť naučí vydávať stabilné výstupy. *Učenie bez učiteľa* - nemá žiadne vonkajšie kritérium správnosti. Učenie je založené iba na informáciách, ktoré samotná sieť získala počas procesu učenia. Poznáme napríklad min-max učenie alebo Hebbovské učenie.

**Vybavovanie** - spracovávajú sa vstupné dáta. V neurónoch zapamätované hodnoty sa začínú meniť pôsobením ostatných neurónov cez spoje a menia sa tak dlho, pokiaľ nenastane stabilný rovnovážny stav. Na výstupe je potom požadovaná odozva siete.[1]

### 3.4 Back-propagation

Tiež sa nazýva algoritmus spätného šírenia, je jedným z najužívanejších algoritmov pre učenie NN. Tento algoritmus je vhodný pre viacvrstvové siete. Využíva metódu učenia s učiteľom. Zaraďuje sa medzi iteračné algoritmy, pre jeho spôsob vypočítavania váh. A patrí tiež medzi gradientné metódy, pretože energetickú funkciu minimalizuje na základe gradientu.

Od neurónovej siete s  $n$  vstupmi a  $m$  výstupmi požadujeme, aby realizovala zobrazenie  $\phi$  z množiny vstupných vektorov  $X \subset R^n$  do množiny výstupných vektorov  $Y \subset R^m$ . NN aproximuje požadované zobrazenie funkciou:

$$\vec{y} = f(\vec{x}, \vec{w}, \vec{\theta}) \quad (3.2)$$

kde  $\vec{y}$  je výstupný vektor,  $\vec{x}$  je vstupný vektor,  $\vec{w}$  je vektor všetkých váh siete a  $\vec{\theta}$  je vektor všetkých prahov. Funkcia  $f$  je určená typom neurónov a topológiou siete. Počas učenia sa táto funkcia nemení, menia sa iba jej parametre  $\vec{w}$  a  $\vec{\theta}$ .

Učiaci algoritmus pre požadované zobrazenie  $\phi: X \rightarrow Y$  nájde také  $\vec{w}$  a  $\vec{\theta}$ , že funkcia  $f$  je práve aproximáciou tohto zobrazenia. Toto zobrazenie popisuje usporiadanú dvojicu vstupný vektor - výstupný vektor, ktorá sa nazýva vzor.

Na presnosť NN má veľký vplyv zvolenie správnej trénovacej množiny. Trénovacia množina obsahuje tisíce vzorov. Dôležité je aby obsahovala všetky významné časti zobrazenia. Data sa získavajú meraním prípadne zberom v nejakom rozsiahlejšom systéme, preto je ťažké určiť ich kvalitu. V praxi sa využívajú fyzikálne znalosti, štatistika alebo experimentálne overovanie.

Princíp algoritmu spätného šírenia sa dá demonštrovať na bežnej učebnej metóde používanej v škole. Žiak v našom prípade NN, je skúšaný v našom prípade možno uvažovať testovanie. Trénovacia množina je považovaná za látku, ktorú sa mal žiak naučiť. Keď žiak látku neovláda musí sa ju doučiť. V prípade NN meníme váhové koeficienty tak dlho, pokiaľ nebude reagovať správne.

Back-propagation je iteračný proces, môžeme ho takto popísať: [1]

```
inicializácia_váh;
repeat
  repeat
    vyber_vzor_z_trénovacej_množiny;
    daj_vybraný_vzor_na_vstupy_siete;
    vypočítaj_výstupy;
    porovnaj_výstupy_so_vzorovými;
    uprav_váhy;
  until prešiel_všetky_vzory_trénovacej_množiny;
until globálna_chyba < kritérium;
```

Najprv sa všetky váhy v sieti nastavujú náhodne na hodnoty v doporučenom rozsahu  $\langle -0.3, 0.3 \rangle$ . Ďalej vyberieme vzor z trénovacej množiny a nastavíme odpovedajúce vstupy. Po vrstvách smerom od vstupu k výstupom siete počítame výstupy jednotlivých neurónov podľa vzťahu:

$$y = S\left(\sum_{i=1}^n w_i x_i + \Theta\right) \quad (3.3)$$

kde výstupná nelineárna funkcia  $S$  je sigmoida definovaná vzťahom:

$$S(\phi) = \frac{1}{1 + e^{-y\phi}} \quad (3.4)$$

kde  $y$  je koeficient, ktorý určuje strmúť krivky v počiatku súradnicovej sústavy. Vstupné a výstupné hodnoty uvažujeme v rozsahu  $\langle -1, 1 \rangle$ . Najčastejšie používaná je hyperbolická tangenta na obrázku 3.4 môžeme sledovať priebeh funkcie. V ďalšom kroku vypočítame energiu, ktorá bude využitá ako prírastok k celkovej energii. Počítame pre všetky vzory podľa vzťahu:


$$E = \frac{1}{2} \sum_{i=1}^n (y_i - d_i)^2 \quad (3.5)$$

kde  $n$  je počet výstupov siete,  $y_i$  je  $i$ -tý výstup a  $d_i$  je  $i$ -tý požadovaný výstup. Táto funkcia považovaná za určitý axiom, bola zvolená na základe určitej úvahy a nemožno ju odvodiť inak.


Ďalej vypočítame chybu pre výstupnú vrstvu pomocou parciálnej derivácie a spätne šírime chybu do vrstvy, ktorá je najbližšie vstupom. Na záver modifikujeme váhy. Ak sme už prešli všetky vzory z trénovacej množiny, kontrolujeme globálnu chybu učenia. Globálna chyba môže byť napríklad stredná kvadratická odchylka, počítaná cez všetky vzory trénovacej množiny. V NN sa počíta energia, čo je miera naučenosti. Globálna chyba je v podstate totožná s energiou, ale na výpočet sa používajú štatistické kritéria.

Ak bola energia za poslednú epochu menšia ako nami zvolené kritérium, tak sa učenie ukončí. Inak pokračujeme ďalšou epochou.

Typický priebeh energetickej funkcie pre dobre naučenú NN je na obrázku 3.3. Existujú prípady, keď sa nám nepodari sieť naučiť s dostatočnou presnosťou. V takomto prípade dosiahne energia určitej hodnoty a prestane klesať. Toto sa nazýva uviaznutie v lokálnom minime.



Obrázek 3.3: Typický priebeh energie počas učenia [1]



Obrázek 3.4: Hyperbolická tangenta

### 3.5 Použitie Neurónových sietí na predikciu

Na burze neexistujú presne dané zákonitosti. Keby existovali, stačilo by vypočítať príslušnú rovnicu a dostali by sme požadovanú hodnotu trhu. Ale zložitosť rozhodovania na burze a

dopredu nejasný smer trhu nás nútia iba odhadovať, ako sa bude cena pohybovať. Rýchle a pomerne presné odhadovanie nám dnes umožňuje výpočtová technika. Obzvlášť dobré výsledky sa dosahujú s použitím neurónových sietí, hlavne siete typu Back-propagation.

Demonštráciu úspešnosti môžeme sledovať napríklad na súťaži v automatickom obchodovaní, ktorá sa uskutočňovala každoročne od roku 2006 do roku 2012 <sup>1</sup>. Tu sa stávali víťazmi a na popredných miestach sa umiestňovali programi, ktoré používali NN.

Takisto môžeme vidieť, že mnoho uznávaných odborníkov používa NN. Jedným z nich je Robert J. Van Eyden, ktorý pochádza Juhoafrickej republiky. Vyvinul systém, ktorý modeluje vývoj burzy v Johannesburgu [5].

---

<sup>1</sup><http://championship.mql5.com/2012/en/>

## Kapitola 4

# Praktická časť

V tejto kapitole budú popísané hlavné body práce. V úvode bude popis dostupných obchodných platforiem a následný výber najvhodnejšej. Ďalej bude popísaný porovnávací model človeka, a navrhnuté modely. Nakoniec budú navrhnuté modely otestované v živom obchodovaní a budú zhrnuté dosiahnuté výsledky.

### 4.1 Obchodná platforma

V dnešnej dobe veľa zariadení ponúka potrebné vlastnosti k ovládaniu obchodných platforiem. Jedná sa hlavne o kvalitné pripojenie k internetu a postačujúci výkon. Vo vývoji sú obchodné platformy pre chytré telefóny, tablety a iné zariadenia. Tieto platformy, ale neponúkajú také možnosti ako platformy vyvinuté pre osobné počítače. Preto v tejto práci ďalej nebudeme týmto platformám venovať pozornosť.

U osobných počítačov rozlišujeme dva základné druhy platforiem. Sú to webové platformy a desktopové platformy. Funkcionalita a vzhľad webových platforiem sú do istej miery limitované webovými technológiami a nutnosťou spolupráce s webovými prehliadačmi. Preto sa im ďalej nebudeme venovať. Poslednou a najpoužívanejšou skupinou platforiem sú desktopové platformy. Každý online borker poskytuje desktopovú aplikáciu, umožňujúcu obchodovanie na burze. Aj tu existuje viacero možností. Broker si môže vytvoriť vlastnú aplikáciu, ktorú ponúkne svojim klientom, alebo môže použiť platformu vyvinutú inou firmou. Typický príklad je platforma Meta Trader vyvinutá spoločnosťou Metaquotes Software Corp, alebo Ninja Trader. Tento prístup používa veľký počet brokerov. V nasledujúcej tabulke 4.1 sú porovnané základné vlastnosti vybraných desktopových obchodných platforiem, ktoré ovplyvnili náš výber koncovej platformy.

Názov	Broker	Prog. jazyk	OS	Demo účet
Jforex	Dukaskopy	java	Win, Linux, Mac	30 dní
Meta Trader	mnoho	mql	Win XP+, (Mac)	neobmedzene
Ninja Trader	mnoho	ninja Script	Win XP+	30 dní
Plus 500	Plus 500	žiadny	Win XP+	neobmedzene
Saxo Trader	Saxo bank	žiadny	Win XP+	20 dní
Trade Station	Trade Station	Easy Language	Win XP+	žiadny
VT Trader	CMS Forex	vlastný	Win XP+	neobmedzene

Tabulka 4.1: Prehľad obchodných platforiem

Pre výber vhodnej platformy je pre nás dôležité, aby sme mohli s platformou komunikovať a následne automaticky obchodovať. K tomu potrebujeme aby platforma bola programovateľná a obsahovala rozhranie pre komunikáciu s okolím. Nemenej dôležitou vlastnosťou je možnosť založiť si demo účet a dĺžka bezplatného používania tohto účtu. Ďalšie vlastnosti sú prevažne informačného charakteru, a neovplyvnia výraznou mierou konečný výsledok nášho rozhodnutia.

Pre túto prácu sa ako najvhodnejšia platforma javí Meta Trader. Meta Trader má aktuálne dve podporované verzie - verzia 4 a verzia 5. My použijeme verziu 4 (ďalej MT4). MT4 je dobre zdokumentovaná platforma a je rozšírená medzi užívateľmi a má rozsiahle oficiálne fórum, kde sa dajú dohľadať odpovede na často vyskítujúce sa otázky. MT4 má užívateľsky prívetivé prostredie s podporou rôznych svetových jazykov, vrátane slovenčiny. Obsahuje vlastný programovací jazyk a používa veľké množstvo brokerov.

## 4.2 Meta Trader a Neurónové siete

Meta Trader obsahuje programovací jazyk Metaquotes language (mql4), ktorý patrí do rodiny jazyka C. Je k nemu sprístupnená celá API. Tento jazyk nám poskytuje celú škálu možností pre automatické obchodovanie. Zabezpečuje rôzne typy obchodných príkazov, používanie indikátorov a nástrojov technickej analýzy. Poskytuje prístup k historickým dátam. Nanešťastie mql4 neobsahuje žiadne rozhranie pre komunikáciu s externými aplikáciami. To je menšia nevýhoda, ale v tejto práci využijeme komunikáciu pomocou externých súborov, ktorá bude popísaná neskôr. Základná verzia mql4 neobsahuje knižnicu, ktorá by podporovala tréning a používanie neurónových sietí. Preto musíme využiť iný spôsob na tréning a predikciu.

Ako najjednoduchšie riešenie sa javí použitie externej knižnice *Fann2Mql*, ktorá je naprogramovaná fanúšikmi MT4 a NN a je šírená pod licenciu GPL. Autori sľubujú ľahké a efektívne použitie. Je umožnená práca s viacerými vláknami. Ale je tu obmedzená manipulácia s výberom tréningového algoritmu. V našej práci budeme používať algoritmus Back-propagation a keďže táto knižnica nie je oficiálne podporovaná, ani správnosť fungovania nie je zaručená, túto knižnicu nebudeme používať.

Existuje možnosť použiť externý program na vytvorenie a naučenie siete, ktorý potom celú sieť uloží do DLL súboru. Tento vytvorený DLL súbor už môžeme používať pomocou mql4. Programy, ktoré toto dokážu spraviť je viacero. Nakoľko sa jedná o netriviálnu a náročnú požiadavku, tieto programy nie sú distribuované vo voľných verziách. Jedinou výnimkou je snáď program *NeuroSolution*. Tento program nám ponúka prívetivé užívateľské rozhranie s veľkou funkčnosťou. Vo svojej 30-dňovej voľnej verzii umožňuje vytvorenie a učenie siete. Problém nastáva pri ukladaní siete do DLL. Tu má voľná verzia zásadné obmedzenia, ktoré nám v tejto práci ďalej neumožňujú používať tento program.

Ďalšou možnosťou je vytvoriť si vlastný program, pomocou ktorého vytvoríme, naučíme sieť a nakoniec budeme pomocou neho vykonávať predpoveď v reálnom čase. Tento program musí byť rýchly, spoľahlivý a musí vedieť komunikovať s MT4. K vytvoreniu takého programu sa nám ponúka celá škála programovacích jazykov s podporou pre prácu s neurónovými sieťami, ako sú napríklad matlab, java alebo python. V tejto práci ďalej budeme používať jazyk python verzie 2.7. K vytvoreniu a tréningu NN, budeme používať knižnicu *PyBrain*. Táto knižnica nám poskytuje všetky potrebné možnosti k vývoju nami požadovanej neurónovej siete.

Teraz ostáva vyriešiť posledný problém. Komunikácia medzi MT4 a našim programom v pythone. Ako už vieme MT4 nemá vytvorené rozhranie, pomocou ktorého by mohlo komunikovať s našim programom. Keďže mi nebudeme odhadovať zmenu kurzu pre každý tick, ale iba raz za požadovaný časový úsek, využijeme komunikáciu typu zapisovanie do externých súborov. Fungovať to bude nasledovne: MT4 na začiatku každej časovej periódy, zvolenom time-frame, zapíše do súboru všetky potrebné informácie o kurze potrebné k predikcií. Naš program z tohto súboru načíta informácie, vymaže ho, spraví predikciu. Nakoniec podľa tejto predikcie a podľa pravidiel, ktoré budú popísané neskôr vyhodnotí ako by sme sa mali zachovať. A do súboru zapíše jeden príkaz z množiny { *KUP*, *DRZ*, *UKONCI*, *PREDAJ* }. MT4 otvorí súbor s príkazom a zistí akú aktivitu má vykonať.

Pomocou MT4 ponúka svoje služby mnoho brokerov, musíme si jedného zvoliť a založiť si demo účet. Demo účet slúži na naučenie a otestovanie vybratej platformy. Sú tu simulované podmienky ako v skutočnom účte. Obchoduje sa tu v reálnom čase so skutočnými dátami, iba peniaze sú imaginárne. Takže nehrozí strata kapitálu pri experimentovaní. Pre výber brokera sme zvolili dve kritéria. Prvým je, aby broker poskytoval nami zvolený trh. Každý broker ponúka balík rôznych trhov k obchodovaniu. Nami zvolený trh (výber je popísaný ďalej) ponúka viacero poskytovateľov. Druhým kritériom je cena služieb. Za brokera sme si zvolili spoločnosť *GKFX Financial Services Ltd*. Táto spoločnosť má v ponuke nami zvolený trh a nemá poplatky za obchod. Zisk si vytvára vďaka spreadu, ktorý je 0,3- 0,4 bodu. Umožňuje nám obchodovať iba za zlomok ceny, vďaka leverage, ktorá sa pohybuje až do hodnoty 400:1. Keďže na uzavretie obchodu nám postačuje iba zlomok ceny aktuálnej ceny transakcie, zvyšok ako keby sme si od nich požičali. Za toto požičanie sa účtuje 2% poplatok.

### 4.3 Výber trhu a testovacie dáta

Vo svete existuje veľké množstvo trhov, kde sa dajú obchodovať rôzne podkladové aktíva. Každý trh je ovplyvňovaný rôznymi vplyvmi. Z nášho intradenného pohľadu je dôležité vybrať taký trh, ktorý bude čo najmenej ovplyvňovaný fundamentálnymi vplyvmi. Ako nevhodné sa javia akciové trhy, kde napríklad vydanie tlačovej správy danej firmy môže nečakane zmeniť vývoj ceny. Obchodovanie s forex je tiež nevhodné. Výsledky z makroekonomických dát alebo prejavy prezidentov národných bánk výrazne ovplyvňujú vývoj ceny. Tento vývoj je z hľadiska technickej analýzy v podstate nepredikovateľný. Z nášho pohľadu sú vhodné indexové trhy. Index môže byť definovaný ako ukazovateľ vývoja cien celého balíka akcií. Keďže je to celý balík akcií, prudká zmena jednej položky balíka, nemá zásadný vplyv na celok.

Dôležitou vlastnosťou pri výbere trhu je aj likvidita. Pokiaľ by trh nebol dostatočne likvidný, naša požiadavka by sa nemusela uskutočniť v požadovanom čase za požadovanú cenu. Pri dostatočne likvidnom trhu môžeme predpokladať, že takáto situácia nenastane a naša požiadavka bude vykonaná ihneď za aktuálnu cenu.

Pre túto prácu je dôležitým faktorom aj dostupnosť historických dát, na ktorých prebehne tréning a testovanie. Internetové zdroje poskytujúce intradenné dáta sú spoplatnené. K dispozícii sú spravidla jedo až troj mesačné dáta. To je pre učenie neurónovej siete nepostačujúce.

Nakoniec sa nám podarilo zohnať dostatočné množstvo dát. Svoje dáta nám poskytol pán Ján Všíansky. Poskytnuté dáta obsahovali tickové dáta rôznych forexových menových párov od januára 1997 do januára 2012. Ďalej máme k dispozícii dáta E-mini Russell 2000



v rozsahu od 15.12.2010 do 24.09.2013.

Z predchádzajúcej analýzy a z dostupných dát nám vyšlo, že najvhodnejší pre nás bude obchodovať E-mini Russell 2000. Tento trh sa teší veľkej popularite a denne je uskutočnených niekoľko miliónov kontraktov. Je to komoditný kontrakt postavený na akciovom indexe Russell 2000, ktorý je počítaný z cien 2000 akcií menších spoločností. Hodnota plného bodu je 100 dolárov. Najmenší pohyb trhu, jeden tick je 0.1 bodu, čo odpovedá hodnote 10 dolárov [2]. Trh sa obchoduje na burze ICE.

Naše dostupné dáta je potrebné si rozdeliť. Jedna skupina dát slúži ako trénovacie dáta. Táto skupina by mala obsahovať podľa možností čo najviac vzorkov. Druhou skupinou je skupina testovacích dát. Pre trénovanie a testovanie nepoužívame dostupné tickové dáta, ale používame dáta už v nami zvolenej time-frame. MT4 definuje pre použitie v programoch základné konštanty time-frame. Z tohto dôvodu budeme používať time-frame 1 minúta a time-frame 5 minút. V nasledujúcej tabulke sú zhrnuté informácie o našich dátach:

	Obdobie	1 minúta	5 minút
<b>Celkový dostupných dát</b>	15.12.2010 - 24.09.2013	253383 vzorkov	53281 vzorkov
<b>Trénovacie dáta</b>	15.12.2010 - 14.12.2012	184143 vzorkov	37754 vzorkov
<b>Testovacie dáta</b>	2.1.2013 - 24.09.2013	69240 vzorkov	15527 vzorkov

Tabulka 4.2: Rozsahy a počty dát

## 4.4 Priebeh testovania

Našu obchodnú stratégiu sme pred testovaním na demo účte, simulovali na historických dátach a porovnali s inými obchodnými stratégiami. Pri porovnaní sme sa snažili čo najviac priblížiť niektorému obchodnému systému človeka. Určenie úspešnosti spočíva v porovnaní celkových ziskov a strát. Náš broker si neúčtuje poplatky za obchod priamo, cena za uskutočnenie obchodu sa v každom momente jemne líši. Spôsob, akým to funguje sme už popísali. Všetky simulácie majú spoločné nasledujúce vlastnosti:

- Krok simulácie je daný zvolenou veľkosťou time-frame.
- Vždy je uzavretý maximálne jeden obchod.
- Za každý obchod je odpočítaný poplatok 0,3 bodu.
- Hodnota obchodu je vypočítaná ako rozdiel medzi vstupnou hodnotou a výstupnou hodnotou trhu, krát hodnota jedného bodu, mínus poplatok.
- Všetky simulácie pracujú s hodnotou prahu 0,5.
- Na konci dňa sa otvorená pozícia uzavretá automaticky, bez ohľadu na výsledky danej stratégie.
- Predpokladáme dostatočnú likviditu trhu, preto sa obchodné príkazy uskutočňujú v okamihu signálu.

- Dĺžka simulovaného obdobia predstavuje 1 mesiac. Takto rozdelené dáta sme dostali a pre lepšiu prehľadnosť ich nebudeme nijako spájať. Mesiac február bol spojený s marcom.

Simulácia každého obchodného systému prebiehala nasledovne:

1. Inicializácia simulácie - nastavenie počiatočného času simulácie a vynulovanie počítačiel.
2. Priebeh všetkými vzorkami v chronologickom poradí od najstaršieho k najnovšiemu.
3. Spracovávanie signálu - vstup alebo výstup z pozície.
4. Výpočet ceny obchodu.
5. Test konca simulácie.
6. Ak nie je koniec simulácie, pokračujem na bod 2.
7. Koniec simulácie.

Výsledky našich testov nemusia presne odpovedať výsledkom v reálnom obchodovaní. Stav na účte počas simulácie môže byť v mínuse, čo by sa v reálnom obchodovaní stať nemohlo. Tento fakt, ale neovplyvňuje náš celkový náhľad na systém, pretože táto práca neskúma Money-managemet. K určeniu či je stratégia zisková nepotrebujeme poznať konečný stav účtu, postačí nám vedieť priemernú cenu jedného obchodu. V simulácii sledujeme v danom období očakávanú cenu(ang. Expected Payoff), čo je priemerná cena jedného obchodu v danom období. Aby sme mohli porovnávať výsledky získané v simulácii s výsledkami z MT4, túto cenu vyjadríme v bodoch(hodnota 1 bodu je 100 \$). Ďalej v našej simulácii sledujeme počet ziskových a stratových obchodov. Z týchto hodnôt môžeme vypočítať úspešnosť uzatvárania ziskových obchodov. Aj tieto faktory nám pomôžu lepšie porovnávať zvolený systém a poskytujú nám komplexnejší pohľad.

## 4.5 Obchodný systém človeka

Vytvoriť počítačový obchodný systém človeka je obtiažne. Obchodník nepracuje strojovo. To znamená, že pri každom signále, ktorý sa vytvorí nevstupuje do obchodu. Obchodník sa celý život vzdeláva a nadobúda praktické skúsenosti. Z toho vyplýva, že v obchodnom systéme človeka, pri jeho rozhodovaní zohrávajú dôležitú úlohu tieto faktory:

- signály zo zvoleného obchodného systému - základom každej akcie je nejaký podnet. Obchodník je naučený určitý obchodný systém, ktorý mu ukazuje signály, na ktoré obchodník môže naučeným spôsobom reagovať.
- pozornosť - signály sa môžu objaviť v hociktorý moment a obchodník si ich hneď nemusí všimnúť. Na burze pri intradenom obchodovaní sa môže cena rapídne meniť behom okamžikov.
- skúsenosti - skúsený obchodník dokáže vypozerovať podľa správania trhu drobné výkyvy v cene a patrične na ne reagovať.
- intuícia, predvídanie - tieto vlastnosti sú prakticky neimplementovateľné. Každý obchodník ich má a nezakladajú sa na žiadnych faktoch.

Naším cieľom nieje vytvoriť dobre fungujúci obchodný systém človeka, ale systém, ktorý bude približne odpovedať systému človeka. Tento obchodný systém využijeme na porovnanie s nami vytvoreným systémom s použitím NN. Zvolili sme si obchodný systém s kľavými priemermi. Tento systém je popísaný v kapitole 2.3. Tento systém sme vylepšili o prahové hodnoty. Týmto sme aspoň z časti dosiahli napodobenie skúseností a intuície v našom systéme človeka.

Nasledujúce tabulky znázorňujú získané výsledky s rôznymi time-frame:

Mesiac	počet obchodov	z toho ziskových	úspešnosť	očakávaná cena
Január	230	78	33.91%	-0.39
Február-Marec	203	76	37.44%	-0.24
Apríl	220	82	37.27%	-0.20
Máj	259	90	34.75%	-0.39
Jún	210	71	33.81%	-0.49
Júl	206	74	35.92%	-0.39
August	202	72	35.64%	-0.16
September	121	38	31.4%	-0.31
Spolu	1651	581	35.19%	-0.32

Tabulka 4.3: Obchodný model človeka. Time-frame 1 minúta.

Mesiac	počet obchodov	z toho ziskových	úspešnosť	očakávaná cena
Január	100	33	33%	-0.69
Február-Marec	91	28	30.77%	-0.33
Apríl	68	20	29.41%	-0.49
Máj	80	32	40%	\$ -0.01
Jún	55	20	36.36%	-0.36
Júl	82	25	30.49%	-1.20
August	55	23	41.81%	-0.03
September	40	16	40%	-0.12
Spolu	571	197	34.5%	-0.45

Tabulka 4.4: Obchodný model človeka. Time-frame 5 minút.

Tento náš model je vo všetkých prípadoch stratový, čo môže viesť k domnienke, že náš model nie je navrhnutý správne. Avšak priemerná strata na jednom obchode je 0,32 bodu respektíve 0,45 bodu. Z toho môžeme usúdiť, že model je pre naše účely dostačujúci. Stratovosť môže byť spôsobená nepoužitím stop-loss a trading-point. Obchodníci vždy používajú stop-loss. Pri prípadnom zlom vývoji ceny trhu je strata obmedzená iba prostriedkami na účte.

## 4.6 Systém použitý v NN

V nasledujúcich podkapitolách je podrobne popísaný náš navrhnutý obchodný systém založený na predpovedi NN. Je vysvetlený postup, detailne sú popísané vstupy a výstupy neurónovej siete. Na konci sú výsledky simulácií na historických dátach.

#### 4.6.1 Koncepcia modelu

Princíp fungovania NN je popísaný v kapitole 3. Pri návrhu modelu si musíme určiť vstupné dáta, ktoré privedieme do systému. Ďalej si musíme definovať výstupné dáta - čo bude systém predpovedať.

Ako vstupné dáta sme zvolili ceny thru a indikátory, ktoré sú základnými prvkami technickej analýzy a môžeme ich získať výpočtom z historických cien. Pomocou týchto prvkov je systém schopný sa naučiť rozpoznávať určité vzory (ang. price patterns), ktoré sa vyskytli v minulosti. Na základe týchto vzorov a ich priebehu v minulosti, systém určí najvhodnejší vzor a predpovie budúci vývoj.

Výstupom systému je priemerná hodnota vo vopred danom časovom období. V tejto práci sa pod pojmom časové obdobie myslí 5 nasledujúcich hodnôt.

#### 4.6.2 Príprava dát

Z našich historických dát sme zistili, že dáta nemusia byť uložené v rovnakom formáte. Dáta sú štandardne uložené v súbore typu CSV (Comma-Separated Values). Hodnoty sa môžu líšiť v type uloženia dátumu a času. Je potrebné si tieto súbory upraviť na jednotný formát. V tejto práci využívame pre dátum formát MM/DD/RRRR a pre čas formát HHMM. Všetky iné formáty sú prevedené.

Historické dáta obsahujú v danom čase hodnotu trhu, volume, počet obchodov v danom čase. Tieto dáta sú tickové. Upravíme ich do požadovaného časového obdobia. Počas tohto obdobia zaznamenávame otváraciu, uzatváraciu, maximálnu a minimálnu cenu.

Ďalej si dopočítame všetky potrebné indikátory technickej analýzy. Vybraté indikátory a ich podrobná definícia je popísaná v teoretickej časti tejto práce. Keď už máme všetky potrebné dáta vypočítané, pre každé časové obdobie, uchováme tieto hodnoty ako vstupné hodnoty. Nakoniec je pre počítaný časový moment uložená aj výstupná hodnota. Výstupná hodnota je vypočítaná ako priemer 5 nasledujúcich uzatváracích cien.

Vstupy NN musia byť v rozsahu od -1,0 do 1,0. Naše hodnoty sa pohybujú v od  $1 \cdot 10^2$  do  $1 \cdot 10^4$ . Vzniká potreba normalizovať tieto hodnoty. Postupov normalizácie existuje viacero. Jedna z možností je zistiť najväčšiu hodnotu v testovacích dátach a ňou podeliť všetky hodnoty. V celej sade našich dát sú odchýlky hodnoty trhu výrazné a takáto normalizácia by mohla skresliť nežiadúcim spôsobom výsledky. Z intradenného pohľadu by bolo najlepšie normalizovať dáta po jednotlivých dňoch s najvyššou dosiahnutou dennou hodnotou. Na historických dátach nieje problém zistiť túto hodnotu. Táto možnosť, ale následne nie je realizovateľná na reálnych dátach, lebo dopredu nepoznáme najväčšiu dennú hodnotu. Z tohto dôvodu sme pristúpili ku kompromisu a k normalizácii využijeme najväčšiu dosiahnutú hodnotu za posledný mesiac. Následne každú hodnotu podelíme najvyššou hodnotou. S tým, že ak aktuálna hodnota bude väčšia ako hodnota normalizácie, bude táto hodnota zaokrúhlená na 1,0.

Okrem cenových hodnôt je potreba normalizovať aj indikátory. Väčšina použitých indikátorov je odvodená od ceny. Tieto hodnoty sú počítané s už normalizovaných hodnôt, a preto ich netreba ďalej upravovať. Výnimku v normalizácii indikátorov tvorí indikátor CCI. U CCI sa uvádzajú ako efektívne hodnoty, hodnoty v rozsahu od -300 do 300. Preto pri normalizácii budeme brať do úvahy 300 ako najväčšiu hodnotu. Prípadné vyššie hodnoty sú zaokrúhlené.

### 4.6.3 Vstupné hodnoty NN

Vstupnou hodnotou do neurónovej siete je vektor. Tento vektor má špecifickú dĺžku a skladá sa z vybraných hodnôt a indikátorov. Tieto hodnoty sú usporiadané za sebou. Vektor sa skladá z týchto historických hodnôt:

- 5 posledných uzatváracích(Close) hodnôt
- Aktuálna otváracia(Open) cena
- MA(5)- kľzavý priemer cien s parametrom 5 hodnôt.
- MA(20)- kľzavý priemer cien s parametrom 20 hodnôt.
- CCI(14)- meria vzťah ceny, kľzavého priemeru a štandardnej odchýlky. Použitý parameter je 14 hodnôt.
- Horná obálka- jednoduchý kľzavý priemer zvýšený o 5%.
- Dolná obálka- jednoduchý kľzavý priemer znížený o 5%.

Optimálne počty všetkých použitých hodnôt, boli vypočítané experimentálne.

### 4.6.4 Výstupné hodnoty NN

Výstupom je jedna priemerná hodnota cien v časovom období 5 hodnôt v budúcnosti. Priemerná hodnota nám pomôže odstrániť výkivy, ktoré ceny prirodzene obsahujú. V rozhodovaní pri vstupe do obchodu, nie je dôležité poznať konkrétnu hodnotu. oveľa dôležitejšie je poznať smer akým sa trh bude uberať. Porovnávaním získanej priemernej hodnoty a aktuálnej ceny, môžeme určiť smer trhu.

### 4.6.5 Zostavenie NN

K zostaveniu neurónovej siete sme použili programovací jazyk Python, veriu 2.7 za pomoci voľne dostupnej knižnice PyBrain.

V predchádzajúcich podkapitolách boli uvedené vstupy a výstupy NN. Každá jedna položka vstupného vektora je reprezentovaná vo vstupnej vrstve jedným neurónom. Vektor sa skladá z 11 položiek, takže aj vstupná vrstva je tvorená 11 položkami. Použijeme 2 skryté vrstvy. Prvá skrytá vrstva sa skladá z počtu neurónov vo vstupnej vrstve na druhú neurónov. Druhá skrytá vrstva obsahuje polovičný počet neurónov z prvej skrytej vrstvy. Výstupná vrstva je reprezentovaná jedným neurónom nakoľko predpovedáme jednu hodnotu.

Trénovanie prebieha pomocou algoritmu *Backpropagation*. Úprava váh a chyby sú odvodené spätne od chyby výstupnej vrstvy. Váhy sú nastavené náhodne automaticky pri vytváraní topológie siete. 20% dát z tréningových dát sú použité ako validačné. Trénovanie potom prebieha na zvyšných dátach. Ukončenie tréningovania nastáva v prípade dosiahnutia maximálneho počtu epoch, alebo pokiaľ celková chyba počítaná na validačných dátach nedosiahne požadovanú hranicu. Posledná podmienka je, keď sa priemerná kvadratická chyba prestane klesať tak ukončíme tréningovanie. V tejto práci sa učenie ukončilo na základe dosiahnutej hranice chyby.

#### 4.6.6 Navrhnuté obchodné modely

Vytvorenie a natrénovanie NN je prvý krok k úspešnej predpovedi ceny trhu. Druhý krok je správne použitie dosiahnutých výsledkov - určenie okamihu vstupu do pozície a výstupu z pozície. V tejto práci sme navrhli dva modely využívajúce tú istú neurónovú sieť. Úspešnosť týchto modelov bude porovnaná na historických dátach aj v reálnom obchodovaní.

Vstupy aj výstupy sú realizované na základe výsledkov NN. V podstate sa jedná o prahovanie výstupov siete. Ideálne by bolo vypočítať výstup neurónovej siete pri každom ticku. Toto riešenie je technicky ťažké, nakoľko sa výstup NN musí vypočítať. A intervaly medzi jednotlivými tickmi nie sú pevne dané. Preto v tejto práci budeme počítať výstup NN vždy v rovnaký okamih. Na začiatku zvoleného časového obdobia. Napríklad pri jedno-minútovej time-frame sa budeme rozhodovať každú minútu.

Výstup NN je priemerná hodnota ceny v nasledujúcich 5 časových jednotkách. Predpokladáme, že cena sa bude pohybovať smerom od aktuálnej ceny k predpovedanej cene. Cena môže prevýšiť našu predpovedanú cenu alebo sa môže pohybovať oveľa nižšie, ale v priemere by sa mala dostať na očakávanú úroveň. Aby bol obchod ziskový musíme k aktuálnej cene trhu pripočítať cenu poplatkov a nejaký predpokladaný zisk. To bude náš prah. Tento prah nám ešte zaručuje, že celková úspešnosť nie je odkázaná iba na presnosť našej NN.


**Model 1** - Tento model je založený na nasledujúcej úvahe. Cena trhu môže rásť, klesať alebo ísť takzvané do strany, kedy sa skoro nemení. Z toho predpokladáme, že môžeme byť počas celého dňa v nejakej pozícii. Pokiaľ pôjde cena do strany tak nebudeme zarábať, ale ani prerábať. A potom keď sa cena pohne, a ak budeme v správnom type obchodu môžeme využiť plný potenciál danej zmeny. Preto keď uzatvoríme jeden typ obchodu, hneď vstúpime do opačného typ obchodu. Napríklad máme uzavretú krátku pozíciu. Dostaneme signál na ukončenie, ukončíme ju a prejdeme do dlhej pozície.

Vstup do pozície je vyhodnocovaný iba za použitia prahu. Keď predpovedaná hodnota prekročí prah je to signál na vstúpenie do pozície. Pri výstupe kontrolujeme ešte jednu podmienku. Môže sa totiž stať, že sme vstúpili do dlhej pozície. V určitom časovom okamžiku sa rozhodujeme, čo spravíme ďalej. Dostávame signál k ukončeniu dlhej pozície. Ale aktuálny profit z obchodu sa pohybuje niekde okolo 0. To znamená, že ešte neboli pokryté náklady na tento obchod a už by sme ho ukončili a otvorili druhý, pri ktorom sa situácia môže opakovať. Takéto obchody sú neefektívne. Tento jav môže byť spôsobený šumom, ktorý týmto postupom z časti eliminujeme. Preto pri otvorení obchodu kontrolujeme profit a pokiaľ sa nachádza v nami zvolenej oblasti neukončujeme obchod.

**Model 2** - Vstup do pozície nastane, keď predpovedaná hodnota prekročí nami zvolený prah. Druhá možnosť vstupu do pozície je keď sme dva-krát po sebe predpovedali rovnaký smer napredovania trhu. Otvorenú pozíciu sa snažíme udržať čo najdlhšie, aby sme pri každom zakolísaní kurzu neukončovali obchod. Preto počas obchodu sledujeme aktuálny profit. Ak aktuálny profit klesne pod určitú hodnotu, pri najbližšej možnosti ukončíme obchod, bez ohľadu na výstup NN. Dá sa to prirovnať k technike stop-loss. Ďalšou možnosťou je, že aktuálny profit presiahne hranicu očakávaného zisku. V tomto prípade skontrolujeme posledných 5 predpovedí, zistíme akým smerom by sa mal trh uberať. Ak je náznak opačného smeru, ako je naša pozícia, pozíciu ukončíme. Posledná možnosť je, že sa pohybuje v pásme medzi povolenou stratou a očakávaným profitom. V tomto prípade kontrolujeme smer trhu pomocou posledných dvoch predpovedí. Ak je signál k zmene smeru trhu, ukončíme

pozíciu.

Hodnoty prahov a hraničné hodnoty pre zisk respektíve stratu boli zistené experimentálne na malej vzorke dát. Na obrázku je znázornený vstup do pozície za pomoci prahu. Modrá kocka je aktuálny stav, v ktorom sa nachádzame, zelená je predpovedaná priemerná hodnota kurzu v nasledujúcom obchode, žlté čiary znázorňujú prah. Na obrázku je zelená kocka pod úrovňou prahu čo značí signál k predaju.



Obrázek 4.1: Vstup do pozície s využitím prahu

#### 4.6.7 Výsledky simulácií

Simulácia navrhnutých modelov pracujúcich na základe neurónovej siete prebehla štandardne definovaným navrhnutým postupom. Výsledky možno pozorovať v nasledujúcich tabulkách. Simulácie prebehli na rovnakých time-frame ako pri obchodnom systéme človeka.

Mesiac	počet obchodov	z toho ziskových	úspešnosť	očakávaná cena
Január	640	528	82.5%	0.67
Február-Marec	218	201	92.2%	1.94
Apríl	532	464	86.73%	1.20
Máj	566	474	83.75%	1.04
Jún	529	468	88.47%	1.34
Júl	117	87	74.36%	0.47
August	546	469	85.90%	0.95
September	368	297	81.71%	0.63
Spolu	3516	2988	84.98%	1.02

Tabulka 4.5: Navrhnutý obchodný model 1. Time-frame 1 minúta.

Obchodný model 1 zaznamenal na oboch testovaných časových obdobiach porovnateľne vysokú úspešnosť uzatvárania ziskových obchodov. V každom mesiaci bol v priemere ziskový. Priemerne zo všetkých vykonaných obchodov dosiahol zisk na jeden obchod 1.01 bodu pri time-frame 1 minúta, čo odpovedá hodnote 101 \$. Pri time-frame 5 minút sa počet uzavretých obchodov znížil 4-krát. Priemerný zisk na jeden obchod ale vzrástol iba 1,6-krát. Výsledný zisk bol 1.61 bodu, čo odpovedá 161 \$ za jeden obchod.

Mesiac	počet obchodov	z toho ziskových	úspešnosť	očakávaná cena
Január	123	101	82.11%	1.44
Február-Marec	145	128	88.28%	1.71
Apríl	163	139	85.28%	2.15
Máj	159	132	83.02%	1.98
Jún	125	111	88.8%	2.17
Júl	15	11	73.33%	0.75
August	113	99	87.61%	2.41
September	57	45	78.94%	2.04
Spolu	900	755	83.88%	1.61

Tabulka 4.6: Navrhnutý obchodný model 1. Time-frame 5 minút.

Mesiac	počet obchodov	z toho ziskových	úspešnosť	očakávaná cena
Január	115	76	66.10%	1.04
Február-Marec	125	97	77.6%	1.55
Apríl	128	93	72.65%	2.16
Máj	134	97	72.39%	1.94
Jún	80	63	78.75%	2.78
Júl	25	6	24%	-1.16
August	83	67	80.72%	2.93
September	43	26	60.47%	2.11
Spolu	733	525	71.62%	1.66

Tabulka 4.7: Navrhnutý obchodný model 2. Time-frame 5 minút.

Model 2 pri time-frame 1 minúta dosiahol skoro 76 percentnú úspešnosť pri priemernom zisku 0.98 bodu (98 \$). Pri simulácií s time-frame 5 minút sme dosiahli o 4 percentá nižšiu úspešnosť obchodov. Počet uzavretých obchodov sa znížil skoro 7 násobne. Priemerná cena za obchod dosiahla hodnotu 1.66 bodu (166 \$).

Zo zistených výsledkov, sme sa rozhodli, že na demo účte budeme testovať naše medely na time-frame 1 minúta. Aj keď je úspešnosť menšia, ako pri 5 minútovej time-frame. Vďaka niekoľko násobne vyššiemu počtu uzatvorených obchodov, je predpoklad väčšieho zisku práve pri 1 minútovej time-frame.

#### 4.6.8 Obchodovanie na demo účte

Založili sme si demo účet, u nami zvoleného brookera - GKFX Financial Services Ltd. K založeniu účtu nám postačil jeden e-mail, ktorý slúžil pre potvrdenie. Tento účet má neobmedzenú dĺžku trvania a neobmedzené množstvo virtuálnych financií. Ďalej sme vytvorili program v MT4 na automatické obchodovanie. Komunikácia s neurónovou sieťou už bola popísaná v kapitole 4.2, ktorá prebehne na začiatku každého časového obdobia. Po ukončení komunikácie, MT4 vykoná určitú činnosť. MT4 rozlišuje príkazy z množiny { *KUP*, *DRZ*, *UKONCI*, *PREDAJ* }.

- *KUP* - skontroluje otvorené obchody. Ak je niektorý obchod otvorený, ukončí ho. Nakúpi aktívum za aktuálnu nákupnú cenu (Ask). Objem nákupu je možné nastaviť pred



Mesiac	počet obchodov	z toho ziskových	úspešnosť	očakávaná cena
Január	1013	635	62.69%	0.46
Február-Marec	241	208	86.31%	1.84
Apríl	768	573	74.61%	0.92
Máj	714	507	71%	0.91
Jún	631	519	82.25%	1.18
Júl	128	74	57.81%	0.22
August	745	532	71.41%	0.79
September	505	330	65.35%	0.53
Spolu	4745	3586	75.57%	0.98

Tabulka 4.8: Navrhnutý obchodný model 2. Time-frame 1 minúta.

spusteným programom. Pri neúspešnom pokuse, nákup opakuje, pokiaľ sa neuskutoční obchod.


- **PREDAJ** - skontroluje otvorené obchody. Ak je niektorý obchod otvorený, ukončí ho. Predá aktívum za aktuálnu predajnú cenu (Bid). Objem nákupu je aj tu možné regulovať pred spusteným programom. Opakuje sa, pokiaľ predaj neskončí úspechom-
- **DRZ** - pri obdržaní tohto príkazu MT4 nič nevykoná - drží aktuálnu pozíciu.
- **UKONCI** - uzatvorí sa aktuálny obchod.

V našom časovom pásme, v letnom období sa obchodovanie s E-mini Russell začína o 15:30 a končí 22:00. Pri výpočtoch indikátor nechceme pracovať s dátami z predchádzajúcich dní. Preto sme začínali obchodovať o 30 minút neskôr. Vstupovať do obchodov tesne pred koncom obchodných hodín je nevýhodné. Cena by sa nemusela dostať na hodnotu, ktorú sme predpovedali, alebo by sme mohli ostať v pozícii aj cez noc. Preto 15 minút pred koncom obchodných hodín už nevstupujeme do pozície. Každú otvorenú pozíciu ukončíme 3 minúty pred záverečnou hodinou a to bez ohľadu na stav v akom sa nachádza.

**Model 1** - testovanie prebehlo počas 5 pracovných dní. Od 14.04.2014 do 21.04.2014. Počas tohto obdobia sme uskutočnili 42 obchodov. Z toho ziskových bolo 18(42.84 %). Priemerná cena jedného obchodu bola 0.21 bodu, čo odpovedá hodnote 21 \$. Tento model v danom časovom období skončil ako ziskový. V nasledujúcej tabulke je prehľad výsledkov. Graf na obrázku 4.2 znázorňuje vývoj stavu účtu po ukončení každého obchodu.

Obdobie	počet obchodov	z toho ziskových	úspešnosť	očakávaná cena
14.04 - 21.04	42	28	42.84%	0.21

Tabulka 4.9: obchodný model 1 - demo účet. Time-frame 1 minúta




Obrázek 4.2: Vývoj stavu demo účtu. Na ose x sledujeme uskutočnené obchody.

**Model 2** - testovanie prebehlo počas 6 pracovných dní. V časovom období 23.04.2014 až 30.04.2014. V tomto období bolo uskutočnených 80 obchodov. Ziskových obchodov bolo 24(30.00 %). Priemerná cena za jeden obchod dosiahla hodnotu -0.36 bodu, čo odvedá hodnote -36 \$. Tento model bol v danom časovom období stratový. V tabulke nájdeme prehľad výsledkov, graf na obrázku 4.3 znázorňuje vývoj stavu účtu v priebehu testovania.

Obdobie	počet obchodov	z toho ziskových	úspešnosť	očakávaná cena
23.04 - 30.04	80	24	30.00%	-0.36

Tabulka 4.10: obchodný model 2 - demo účet. Time-frame 1 minúta



Obrázek 4.3: Vývoj stavu demo účtu. Na ose x sledujeme uskutočnené obchody.

#### 4.6.9 Porovnanie výsledkov

Na začiatku sme si určili spôsob hodnotenia, ako porovnávanie výsledkov navrhnutých modelov s jednoduchým modelom človeka. Ako hlavný faktor porovnania je zvolená priemerná cena jedného obchodu. Následne porovnáme výsledky navrhnutých modelov. Výsledky zistené simuláciou na historických dátach s výsledkami z demo účtu.

V tabulkách 4.11 a 4.12 môžeme pozorovať celkové výsledky simulácií daných modelov. Môžeme vidieť, že naše navrhnuté modely sú vo všetkých prípadoch ziskové. Pri porovnaní

s obchodným systémom človeka sme zistili, že obchodné systémy využívajúce neurónové siete sú profitabilnejšie. Uzatvorí sa v danom časovom období viac obchodov, potenciál trhu je lepšie využitý. Vzástla aj úspešnosť uzatvárania ziskových obchodov a to viac ako dvojnásobne. Celkový zisk z jedného obchodu je tiež väčší. Pomocou týchto výsledkov môžeme našu hypotézu, ktorá tvrdí, že obchodný systém pracujúci na základe umelých neurónových sietí je ziskovejší ako obchodný systém človeka, považovať za pravdivú.

Model	počet obchodov	z toho ziskových	úspešnosť	očakávaná cena
človek	1651	581	35.19%	-0.32
model 1	3516	2988	84.98%	1.02
model 2	4745	3586	75.57%	0.98

Tabulka 4.11: Porovnanie obchodných modelov time-frame 1 minúta.

Model	počet obchodov	z toho ziskových	úspešnosť	očakávaná cena
človek	571	197	34.50%	-0.45
model 1	900	755	83.88%	1.61
model 2	733	525	71.62%	1.66

Tabulka 4.12: Porovnanie obchodných modelov time-frame 5 minút.

V tabulke 4.13 môžeme pozorovať výsledky dosiahnuté obchodnými systémami využívajúcimi neurónové siete na historických dátach a výsledky dosiahnuté v reálnom obchodovaní na demo účte pri použití time-frame 1 minúta. Môžeme pozorovať, že výsledky dosiahnuté na demo účte nenaplnili naše očakávania na 100 %. Konečná úspešnosť modelov na demo účte bola nižšia ako očakávaná. Avšak model 1 aj napriek tomuto faktoru skončil v priemere so ziskom. Výsledky modelu 2 sú porovnateľné s výsledkami modelu človeka.

Model	typ testu	úspešnosť	očakávaná cena
model človeka	historické dáta	35.19%	-0.32
model 1	historické dáta	84.98%	1.02
model 1	demo účet	42.84%	0.21
model 2	historické dáta	75.57%	0.98
model 2	demo účet	30.00%	-0.36

Tabulka 4.13: Porovnanie výsledkov historický dát a výsledkov z demo účtu .

#### 4.6.10 Návrh ďalšieho vývoja

Navrhnuté systémy sa javia ako funkčné, sú úspešnejšie ako zvolený model človeka. Stále ostáva potenciál využiť niektoré príležitosti, ktoré neboli vôbec využité, alebo boli využité iba čiastočne. Pri zachovaní aktuálnej koncepcie sú navrhnuté nasledujúce smery ďalšieho vývoja.

Po analýze uskutočnených obchodov a ich priebehu sme zistili, že niektoré obchody by vykazovali väčšiu efektívnosť pri skoršom alebo naopak pri neskoršom ukončení. Preto by sa ďalší vývoj mal zaoberať návrhom lepšieho vystúpenia z obchodu.

Ako vstupná hodnota je zvolená kombinácia indikátorov. Táto kombinácia bola navrhnutá na základe experimentov v kombinácii s informáciami z literatúry. Avšak každá jedna zmena ovplyňuje výstup. Preto lepšia kombinácia indikátorov, alebo ich nastavenie, veľkosť neurónovej siete, veľkosť prahu a mnohé iné faktory, môžu výsledok ešte zlepšiť.

Ako najdôležitejšia úprava sa javí, zrýchlenie komunikácie medzi programom realizujúcim predpoveď a MT4. Prípadne implementovať vlastnú neurónovú sieť priamo v MT4. Naša komunikácia trvá 3-4 sekundy. Za tento čas sa môže trh zmeniť a podmienky, pri vstupe a výstupe už nie sú také ako sme predpokladali pri výpočte.

## Kapitola 5

# Záver

Cielom tejto práce bolo vytvoriť systém, využívajúci neurónovú sieť k predpovedi vývoja ceny trhu. Pre túto sieť zvoliť vhodné vstupné parametry. Otestovať ziskovosť systému na zvolenej platforme.

Podľa názoru niektorých ľudí je vývoj ceny trhu úplne náhodný a teda nepredpovedateľný. V tejto práci bolo opäť preukázané, že neurónové siete sú schopné do určitej miery sa naučiť a predpovedať vývoj ceny trhu.

Pri návrhu modelu a práci s historickými dátami sme zo štatistického hľadiska dosiahli uspokojivých výsledkov. Navrhnuté modely sú ziskové. Avšak pri podrobnej analýze jednotlivých uskutočnených obchodoch, sme zistili, že naše modely využívajú iba časť potenciálu, ktorý sa v trhoch skrýva. Tu je však na mieste otázka do akej miery je ešte možné vylepšiť automatické obchodovanie.

Výsledky dosiahnuté pri obchodovaní v reálnom čase na demo účte, nenaplnili naše očakávania. Simulácie boli úspešnejšie, ako výsledky z praxe. Napriek tomu jeden náš model dosiahol ziskový výsledok. Pokles úspešnosti v reálnom obchodovaní oproti simuláciám mohol byť spôsobený viacerými faktormi. Jedným z faktorov môže byť nedostatočné zobecnenie skutočnosti v našej simulácii. Napríklad v simulácii pri vstupe do pozície uvažujeme aktuálny kurz, kdežto v reálnom obchodovaní vstupný kurz do pozície je odlišný od aktuálneho. Veľkosť odchýlky nie je pevne daná, nastavuje ju broker priebežne. V simulácii sa tento fakt snažíme napodobniť, ale je tu priestor pre odchýlky. V simulácii počítame s dostatočnou volatilitou, ktorá nie je zaručená v reálnych obchodoch. Ďalší a podľa môjho názoru rozhodujúcejší faktor je pomalá komunikácia medzi MT4 a predpovedajúcim programom. Komunikácia trvá približne 3 sekundy. Za tento čas sa môže cena kurzu vychýliť od predpokladanej ceny, a tým pádom aj výrazne ovplyvniť výsledok.

Ako už bolo zmienené, ďalší vývoj by sa mal zaoberať zrýchlením komunikácie programu vykonávajúceho predpoveť s obchodnou platformou a tiež hľadaním optimálnejších vstupných parametrov neurónovej siete a hľadaním efektívnejšieho ukončenia obchodu.

# Literatura

- [1] Doc.Ing.Miroslav Šnorek, C.; Ing. Marcel Jiřina, D.: *Neuronové sítě a neuropočítače*. České Vysoké Učení Technické v Praze, 1996, ISBN 80-01-01455-X.
- [2] Podhajský, P.; Nesnídal, T.: *Kompletný průvodce úspěšného finančníka*. Centrum finančního vzdělávání,s.r.o., 2010, ISBN 978-80-903874-5-4.
- [3] Prof.Ing.Jiří Bíla, D.: *Umělá inteligence a neuronové sítě v aplikáciach*. České Vysoké Učení Technické v Praze, 2011.
- [4] Putna, L.: *Predikce vývoje kurzu pomocí umělých neuronových sítí*. FIT VUT v Brně, 2011.
- [5] VanEyden, R. J.: *The Application of Neural Networks in the Forecasting of Share Prices*. Finance and Technology, 1996, ISBN 978-0965133203.

## Příloha A

### Obsah CD

CD obsahující všechny zdrojové kódy , jednoduchý návod na použití zdrojových kódů.  
Sada dat na testování jednotlivých zdrojových kódů.